

Aplicación de las Redes Neuronales al Pronóstico de Precios en el Mercado de Valores

Fernando Villada, Nicolás Muñoz y Edwin García

Universidad de Antioquia, Fac. de Ingeniería, Depto Ing. Eléctrica, Calle 67 No. 53-108, Oficina 19-441, Medellín-Colombia (e-mail: fvillada@udea.edu.co)

Recibido Nov. 04, 2011; Aceptado Dic. 26, 2011; Versión final recibida Ene. 12, 2012

Resumen

Este trabajo propone un modelo basado en redes neuronales artificiales para el pronóstico de los precios de dos de las principales acciones transadas en mercado de valores colombiano. El modelo propuesto se aplica al estudio de las acciones de Ecopetrol y Preferencial Bancolombia, empresas que negocian en las bolsas de valores de Colombia y Nueva York. Se utilizan dos estructuras de redes incluyendo como entradas la serie de precios diarios en la primera y la serie de precios más el índice del dólar estadounidense DXY en la segunda. Se prueban diferentes configuraciones de redes neuronales utilizando una serie de seis meses, donde los datos de los primeros cinco se utilizan para entrenamiento dejando el último mes para verificar la capacidad predictiva de la red. Los resultados muestran un buen comportamiento de las redes neuronales con bajos errores en su desempeño tanto en aprendizaje como en predicción.

Palabras clave: mercado de valores, redes neuronales artificiales, pronóstico de precios

Application of Artificial Neural Networks to Price Forecasting in the Stock Exchange Market

Abstract

An artificial neural network model to forecast the price of two of the main shares traded in the Colombian stock exchange is proposed in this work. The model is applied to study the shares of Ecopetrol and Preferencial Bancolombia, companies that trade in the stock exchanges of Colombia and New York. Two network structures including the daily price series in the first and the price series plus the dollar index DXY in the latter are used. Different neural networks configurations are trained using a series of six months, where five months are used as training patterns and the next month is left to test the predictive capabilities of the network. The results show good performance of the neural networks with low training and testing errors.

Keywords: stock exchange market, artificial neural networks, price forecasting

INTRODUCCIÓN

Los mercados financieros son aquellos donde concurren los entes deficitarios y superavitarios de capital, los primeros con el objetivo de obtener financiación y los segundos invertir sus excedentes de recursos. Las acciones sobre empresas son los títulos más transados comúnmente en un mercado de valores, el cual a su vez es un componente fundamental de los mercados financieros. El pronóstico del precio de las acciones es por lo tanto de alto interés para los inversionistas ya que le indicará las señales de compra o venta de estos títulos con el fin de maximizar sus beneficios, sin embargo, no es una tarea fácil dada la cantidad de variables macroeconómicas y microeconómicas que determinan su valor (Hadavandi et al., 2010).

En el contexto colombiano, el mercado de valores ha tomado gran importancia por su crecimiento sostenido durante los últimos nueve años dada la recuperación de la confianza inversionista. Esto además ha permitido la creación de otro mercado importante como es el de derivados y la integración con otras bolsas en el llamado Mercado Integrado Latino Americano (MILA) que agrupo a las bolsas de valores de Chile, Perú y Colombia (www.mercadointegrado.com).

Esta situación ha llevado a tener un número cada vez mayor de empresas nacionales y extranjeras cotizando en la bolsa de valores de Colombia y que algunas de nuestras principales acciones se negocien simultáneamente en las bolsas de Colombia y Nueva York, Colombia y Toronto o Colombia y Madrid. Por esa razón se hace cada vez más pertinente el estudio de modelos que permitan pronosticar el comportamiento de las acciones transadas en la bolsa de valores de Colombia de tal forma que se constituyan en una guía que oriente la estrategia a seguir por los inversionistas participantes.

Unas de las técnicas matemáticas utilizadas para abordar el estudio del comportamiento de mercados financieros han sido los modelos multivariantes y univariantes, pero presentan deficiencias cuando se trata de realizar predicciones fuera de la muestra (Meese y Roesse, 1991). Estudios posteriores han demostrado que la presencia de dinámicas no lineales podría implicar la posibilidad de realizar predicciones más precisas que aquellas proporcionadas por un modelo estocástico lineal y, en concreto, por el modelo paseo aleatorio. En este sentido, autores como Fernández y Sosvilla (1998), proveen evidencias en favor de la predicción no-lineal de los tipos de cambio. Otros autores han utilizado métodos estocásticos basados en cadenas de Markov con el fin de afrontar los estados aleatorios en el comportamiento de estos mercados (Zhang y Zhang, 2009). A pesar de no entregar un valor concreto de pronóstico, su ventaja se da en que permite predecir cambios posibles en los estados de los precios en términos de probabilidad de ocurrencia. Su aplicación al mercado financiero chino mostró la utilidad del método en términos de disponer un criterio adicional a los pronósticos entregados por otros métodos basados en series de tiempo.

Como estrategia de control del riesgo y para la valoración de derivados financieros sobre acciones e índices, otros estudios han tratado el problema de pronóstico de la volatilidad. En este sentido Yalama y Sevil (2008) emplean diferentes clases de modelos GARCH con el fin de pronosticar la volatilidad diaria de los principales índices de los mercados de valores en 10 países diferentes. Como resultado encuentra un mejor desempeño de los modelos de volatilidad asimétrica con respecto a los modelos históricos. Otro trabajo emplea la combinación de los métodos GARCH, EGARCH, paseo aleatorio y promedios móviles exponenciales para predecir el comportamiento de la volatilidad en los mercados de valores (Jing-rong, 2007). Su aplicación al índice de la bolsa de Shenzhen en la China, arrojó que el modelo propuesto entregaba errores inferiores al obtenido con los pronósticos de modelos individuales.

Ante el comportamiento no lineal de este tipo de variables económicas, desde la década de los 90 se han propuesto nuevos métodos basados en redes neuronales artificiales. Su principal característica de permitir establecer relaciones lineales y no lineales entre las entradas y salidas de un sistema ha hecho posible mostrar su aplicabilidad en mercados de alta volatilidad, cuyas variables obedecen a comportamientos no lineales en diversas áreas de la ingeniería y en los mercados de electricidad (García et al., 2008; Villada et al., 2011). Una primera revisión donde se

muestra un conjunto amplio de aplicaciones exitosas de las redes neuronales a las finanzas se presenta en Trippi y Turban (1996). En este libro se destacan trabajos de análisis de reportes contables, predicción de quiebras, análisis de riesgo, pronóstico de divisas y estrategias de negociación de índices financieros entre otros. En una publicación reciente, Li y Ma (2010) presentan una revisión actualizada de estas aplicaciones a predicciones en los mercados de valores, derivados, divisas y crisis financieras. De estas revisiones se resalta la superioridad en el desempeño de las redes neuronales con respecto a los métodos econométricos y otros modelos lineales.

Durante los últimos años las redes neuronales se encuentran formando una terna conjuntamente con la lógica difusa y los algoritmos genéticos. Bekiros y Georgoutsos (2007) compararon el desempeño de una red neuro-difusa con respecto a una red neuronal en la tarea de predecir la dirección del mercado para el caso de los índices NASDAQ y NIKKEI. Se encontró que una estrategia de negociación basada en la indicación de ambos modelos es superior con respecto a una estrategia de comprar y mantener el índice. Adicionalmente, los resultados del modelo neuro-difuso fueron superiores al modelo neuronal ya que tuvieron mayor acierto en la predicción de su dirección.

Una revisión de 100 publicaciones científicas dedicadas al pronóstico de precios en los mercados de valores de diferentes partes del mundo usando redes neuronales y redes neuro-difusas es presentada por Atsalakis y Valavanis (2009). Todos estos trabajos demuestran la superioridad de estas técnicas de computación inteligente con respecto a los modelos convencionales en cuanto a una mejor precisión en el pronóstico. Sin embargo anotan la dificultad en la definición en la estructura del modelo pues en la mayoría de los casos se realizó por prueba y error. Sin embargo, Chen et al. (2011) comparó el desempeño de modelos basados en series de tiempo y lógica difusas con un algoritmo también basado en series de tiempo pero modificando las entradas a la variación del precio y el signo de la tendencia. En su aplicación al índice del mercado de valores de Taiwán se encontró que el modelo propuesto superaba en gran parte de los casos al pronóstico con modelos AR, ARMA y lógica difusa.

En la literatura científica se encuentran también modelos que combinan redes neuronales con algoritmos genéticos. Hao (2010) propone una red neuro-genética para pronosticar el precio de las acciones en el corto plazo en la bolsa de valores de Shenzhen (China), la cual combina la capacidad de búsqueda de los algoritmos genéticos con el fin de determinar los pesos óptimos de la red neuronal. El modelo propuesto arrojó muy buenos resultados en el pronóstico de los cuatro días siguientes, sin embargo, el error era mayor aumentando el número de días o al tratar de abordar el problema con datos semanales.

Un modelo híbrido utilizando algoritmos genéticos, lógica difusa y redes neuronales es propuesto por Hadavandi et al. (2010). Su aplicación al pronóstico de precios de dos acciones tecnológicas y dos aerolíneas arrojaron un mejor desempeño en el modelo al compararlo con trabajos similares que utilizaban redes neuronales o lógica difusa de manera individual.

Dado que la mayoría de referencias consultadas se han enfocado al pronóstico de precios en mercados financieros maduros ubicados en países desarrollados y que en trabajos previos de nuestro grupo de investigación se ha encontrado un mejor desempeño de los modelos de inteligencia artificial en el pronóstico de precios en los mercados de electricidad y de divisas; en este trabajo se propone un modelo basado en redes neuronales para el pronóstico del precio en dos de las acciones más importantes del mercado de valores colombiano. El modelo propuesto se aplica al estudio del precio de las acciones de Ecopetrol y Preferencial Bancolombia teniendo en cuenta que ambas se negocian simultáneamente en las bolsas de valores de Colombia y Nueva York. Se prueban diferentes estructuras de redes neuronales utilizando la serie de precios y el índice del dólar estadounidense de seis meses, donde los datos de los primeros cinco se utilizan para entrenamiento dejando el último mes para pronóstico. Los resultados demuestran la aplicabilidad y buen comportamiento de las redes neuronales en mercados emergentes como el colombiano, obteniendo bajos errores en su desempeño tanto dentro como fuera de la muestra.

REDES NEURONALES ARTIFICIALES

Una red neuronal es un sistema que permite establecer una relación lineal o no lineal entre las salidas y las entradas. Sus características están inspiradas en el sistema nervioso lo que les da varias ventajas tales como su capacidad de aprendizaje adaptativo, son auto-organizativas, pueden funcionar en paralelo en tiempo real y ofrecen tolerancia a fallos por la codificación redundante de la información.

Desde el punto de vista de solucionar problemas, las redes neuronales son diferentes de los computadores convencionales que usan algoritmos secuenciales, mientras que las redes neuronales actúan como el cerebro humano, procesando la información en paralelo, y también pueden aprender y generalizar a situaciones no incluidas en el proceso de entrenamiento. Las redes neuronales pueden procesar información de forma más rápida que los computadores convencionales, pero tienen la desventaja de que no podemos seguir su respuesta paso a paso como se puede hacer al ejecutar un programa convencional en un ordenador por lo que no resulta fácil detectar los errores.

Las redes neuronales artificiales son muy efectivas para resolver problemas complicados de clasificación y reconocimiento de patrones. La más utilizada es la llamada de propagación hacia adelante. La figura 1 muestra una red de propagación hacia adelante con dos capas ocultas. El número de entradas es directamente dependiente de la información disponible para ser clasificada mientras que el número de neuronas de salida es igual al número de clases a ser separadas. Las unidades de una capa se conectan unidireccionalmente con las de la siguiente, en general todas con todas, sometiendo a sus salidas a la multiplicación por un peso que es diferente para cada una de las conexiones.

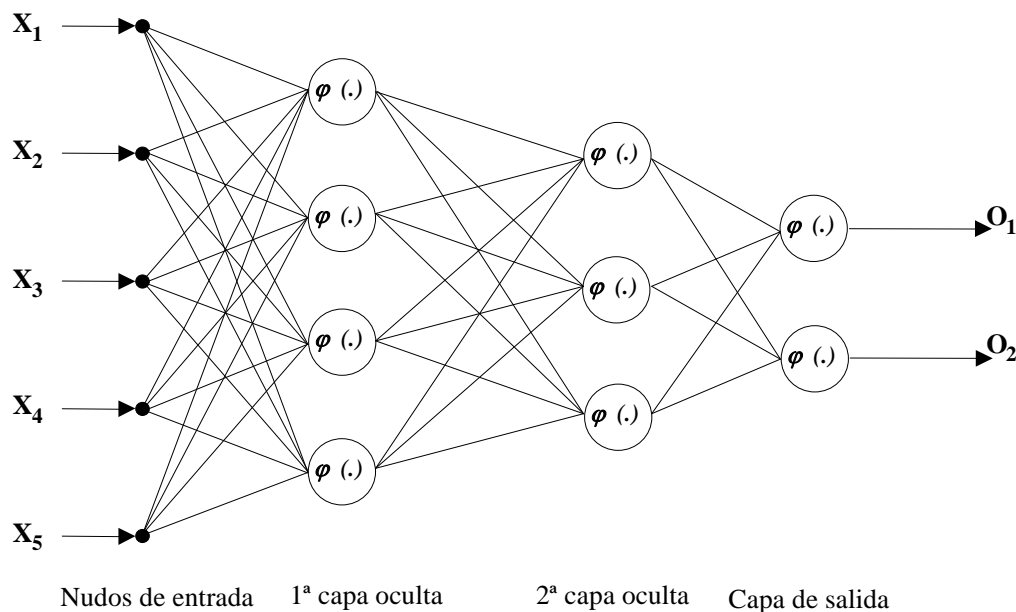


Fig. 1: Red neuronal de propagación hacia adelante

Las Redes Neuronales Artificiales han sido empleadas para resolver numerosos problemas. Entre estos están los económicos y financieros, destacando en gran medida su aplicación en la predicción de series temporales y su capacidad para detectar y explotar la no-linealidad existente en los datos, aun en condiciones donde existen datos incompletos o la presencia de ruido; también se destacan por su desempeño en la solución de problemas complejos, donde el reconocimiento de modelos o comportamientos es importante.

REDES NEURONALES Y PRONÓSTICO DEL PRECIO DE ACCIONES

Para el desarrollo del modelo se procedió a recopilar los datos históricos del precio de las acciones de Ecopetrol y preferencial Bancolombia, las cuales se negocian simultáneamente en las bolsas de valores de Colombia y Nueva York. Esta información fue obtenida del sitio web de la bolsa de valores de Colombia (www.bvc.com.co). Las variables de entrada corresponden a los precios de cierre diarios en pesos colombianos y como salida única se tiene el precio a pronosticar para el día siguiente.

La red que se utilizó fue el perceptrón multicapa con conexiones hacia adelante, porque dentro del marco de las redes de neuronas, el perceptrón ha mostrado ser una de las arquitecturas más útiles en la resolución de este tipo de problemas. Esto es debido, fundamentalmente, a su capacidad como aproximador universal. La arquitectura de esta red, se caracteriza porque tiene sus neuronas agrupadas en capas de diferentes niveles. Cada una de las capas está formada por un conjunto de neuronas y se distinguen tres tipos de capas diferentes: la capa de entrada, la capa de salida y la capa oculta. Cada neurona posee su respectivo nivel de umbral y la función de transferencia utilizada en todas las neuronas fue la tangente hiperbólica.

Algoritmo de Aprendizaje

La regla o algoritmo de aprendizaje es el mecanismo mediante el cual se van adaptando y modificando todos los parámetros de la red. En el caso del perceptrón multicapa se trata de un algoritmo de aprendizaje supervisado; es decir, la modificación de los parámetros se realiza para que la salida de la red sea lo más próxima posible a la salida proporcionada por el supervisor o salida deseada. Por tanto, el proceso de aprendizaje de la red es equivalente a encontrar un mínimo de la función error. El algoritmo de aprendizaje utilizado fue del tipo Levenberg Marquardt porque en general ha mostrado tener una convergencia más rápida, es decir, requiere menor cantidad de iteraciones para llegar al nivel de error especificado.

Proceso de Aprendizaje

El objetivo del aprendizaje o entrenamiento de la red, es ajustar los parámetros de la red, pesos y umbrales, con el fin de que las entradas presentadas produzcan las salidas deseadas, es decir con el fin de minimizar la función de error. En lo que respecta al número de capas y neuronas por capa, no existe un método o regla que determine el número óptimo de neuronas ocultas para resolver un problema dado, generalmente se determinan por prueba y error, es decir partiendo de una arquitectura ya entrenada, se realizan cambios aumentando y disminuyendo el número de neuronas ocultas y el número de capas hasta conseguir la arquitectura que se ajuste a la solución del problema. La selección de la mejor estructura en este trabajo se determinó por medio de las medidas tradicionales de evaluación del pronóstico dentro y fuera de la muestra, descritas en la siguiente sección.

Modelo de pronóstico con redes neuronales

En este trabajo se probaron diferentes estructuras de redes neuronales con una capa oculta, partiendo de un número de neuronas igual al promedio entre el número de entradas y el número de salidas. Luego se incrementó gradualmente el número de neuronas en dicha capa hasta obtener la estructura más recomendable para el pronóstico del precio de las acciones estudiadas. La selección de la mejor estructura de red, se realiza considerando las siguientes medidas de evaluación dentro y fuera de la muestra: RMSE (Raíz del error medio cuadrático) y el MAPE (Error absoluto porcentual promedio), calculados mediante las ecuaciones 1 y 2.

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y'_t - y_t)^2} \quad (1)$$

$$MAPE = \frac{100}{n} \sum_{t=1}^n \left| \frac{y'_t - y_t}{y_t} \right| \quad (2)$$

Donde n es el número de observaciones consideradas, y_t es el precio real y y'_t es el precio estimado por el modelo.

Este trabajo está dirigido a las necesidades de un swing trader operando en la bolsa de valores de Colombia, cuyo objetivo fundamental es tener una idea del valor futuro de una acción en los próximos días; de esta forma se escogió un horizonte de predicción de un mes para el cual se encontró que la red neuronal se entrenaba adecuadamente con los datos de los cinco meses anteriores. En la tabla 1 se presentan los resultados para las acciones de Ecopetrol y Preferencial Bancolombia respectivamente con las medidas de evaluación dentro y fuera de la muestra de las diferentes estructuras de red entrenadas; donde r corresponde al número de rezagos considerados y nn el número de neuronas en la capa oculta. De un conjunto total de 124 datos de precios de cierre diarios correspondientes a seis meses de negociación comprendidos entre el 1 de abril de 2011 y el 30 de septiembre 2011, se tomaron 102 para entrenamiento (cinco meses) y se dejaron 22 datos correspondientes a un mes completo para pronóstico fuera de la muestra.

Tabla 1: Desempeño del valor de las acciones con una variable de entrada

r	nn	Desempeño de la acción de Ecopetrol				Desempeño de Preferencial Bancolombia			
		Dentro de la muestra		Fuera de la muestra		Dentro de la muestra		Fuera de la muestra	
		RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE
2	2	45.24	0.9294	76.14	1.5266	415.81	1.0587	468.12	1.3806
	4	44.36	0.8846	75.96	1.5022	374.02	0.9834	484.26	1.3692
	6	42.79	0.8620	74.34	1.4545	328.51	0.8813	439.71	1.2847
	8	38.10	0.7770	69.19	1.4385	300.43	0.8116	462.33	1.2621
3	2	43.47	0.9075	75.51	1.5258	495.69	1.2073	446.03	1.3390
	3	44.19	0.9134	71.49	1.4890	340.22	0.9276	464.63	1.3273
	6	39.63	0.8051	72.74	1.4878	313.04	0.8130	474.88	1.2933
	9	36.61	0.7507	71.88	1.3886	327.93	0.8584	536.03	1.5722
4	4	39.45	0.7542	77.90	1.4923	310.65	0.7777	451.96	1.3219
	6	34.22	0.6668	69.91	1.4606	280.46	0.7398	493.43	1.4295
	8	28.17	0.5361	83.15	1.7788	273.12	0.6944	556.92	1.5752
	10	26.36	0.5036	74.75	1.4351	158.96	0.3586	632.04	1.6023
5	4	30.98	0.6271	76.19	1.5518	271.48	0.7159	508.30	1.4732
	6	29.11	0.5484	78.18	1.5829	238.63	0.5940	504.40	1.5500
	8	22.80	0.3822	79.26	1.5902	373.21	0.8505	489.90	1.5569
	10	12.62	0.2126	84.60	1.8168	225.89	0.4025	705.67	1.9957

Los resultados de la tabla 1 muestran en general un buen desempeño de las estructuras de redes estudiadas para modelar el comportamiento de ambas acciones, sin embargo, se destacan los indicadores de la estructura 2/8/1 con dos rezagos de tiempo en la capa de entrada y 8 neuronas en la capa oculta donde se tienen unos errores bajos tanto dentro como fuera de la muestra. Se aprecia como una misma estructura de red es suficiente para describir ambas acciones.

Dado el impacto que tiene la situación económica de los países ricos sobre el comportamiento de las bolsas de valores de las economías emergentes, se involucra en el análisis una segunda variable de entrada que pretende medir dicho efecto sobre las acciones analizadas. En este caso se escogió el índice del dólar americano DXY, el cual pondera diariamente el comportamiento del dólar estadounidense frente a una canasta de las seis monedas más importantes (<http://investigaciones.bancolombia.com/espanol/glosariobco/glosarioGrupo2.asp>). En la última década se ha podido apreciar que este índice ha mantenido una buena correlación con el desempeño de la economía mundial, depreciándose en épocas de alto crecimiento y apreciándose en temporadas de crisis o incertidumbre, ya que en este último caso los inversionistas liquidan sus activos en renta variable en las economías emergentes buscando refugio en el dólar americano.

En la tabla 2 se muestran los resultados para las estructuras de red con dos variables de entrada, observándose una leve mejoría en los indicadores de desempeño para el caso de dos rezagos de tiempo. Se destaca que siguen siendo coherentes los resultados de cada estructura para ambas acciones estudiadas. Un número de rezagos de tiempo superior a dos, empeora el desempeño de la red dado que se aprecia un incremento en los indicadores.

Tabla 2: Desempeño del valor de las acciones con dos variables de entrada

r	Nn	Desempeño de la acción de Ecopetrol				Desempeño de Preferencial Bancolombia			
		Dentro de la muestra		Fuera de la muestra		Dentro de la muestra		Fuera de la muestra	
		RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE
2	2	43.15	0.8764	72.24	1.4354	383.69	1.0254	473.55	132.67
	4	39.11	0.7862	73.63	1.4601	346.34	0.8840	434.90	1.2453
	6	32.06	0.6406	74.83	1.4084	286.17	0.6829	500.49	1.3723
	8	33.09	0.6596	71.77	1.4365	177.02	0.4495	618.40	1.7669
3	2	43.35	0.8371	73.87	1.4918	357.51	0.9896	495.60	1.4115
	3	36.57	0.7149	77.88	1.5745	336.76	0.8568	467.43	1.3968
	6	33.63	0.6326	79.85	1.5194	245.90	0.5506	619.85	1.6650
	9	31.98	0.5722	82.95	1.4793	72.81	0.1586	593.20	1.9058
4	4	31.27	0.6144	75.51	1.5877	220.71	0.4820	420.42	1.2113
	6	28.03	0.4898	74.31	1.6185	204.95	0.4550	479.17	1.4397
	8	23.03	0.3774	104.50	2.1369	68.50	0.1167	561.89	1.6874
	10	11.79	0.1568	111.43	2.4678	76.17	0.1017	861.04	2.5544
5	4	34.77	0.6495	84.83	1.8287	311.35	0.7124	659.07	1.9826
	6	19.04	0.2795	77.32	1.5396	93.41	0.1986	697.93	1.9334
	8	13.84	0.1607	88.04	1.8894	64.92	0.1312	864.98	2.3745
	10	0.01	0.0001	116.54	2.5006	183.40	0.3820	812.34	1.4433

ANÁLISIS DE RESULTADOS

Las estructuras encontradas de redes neuronales mostraron un buen comportamiento dentro y fuera de la muestra. Un número de neuronas en la capa oculta superior a seis, ocasiona una disminución de los indicadores de error dentro de la muestra a la par con un incremento de los

mismos fuera de la muestra, lo cual indica que en estos casos la red memoriza cada vez más los datos de entrenamiento pero pierde la capacidad de generalización. Dado que la hipótesis de un mejor desempeño de las redes al incorporar el índice del dólar estadounidense DXY como segunda variable de entrada se cumplió parcialmente, es decir, para el caso de dos rezagos de tiempo; se procedió a entrenar nuevas estructuras de redes con diferentes rezagos de tiempo en el precio pero acotando el índice DXY a dos rezagos.

En la tabla 3 se muestran las mejores estructuras encontradas tomando como referencia los indicadores de desempeño fuera de la muestra. En el caso de Ecopetrol se tiene una estructura con seis neuronas en la capa oculta, donde la red RNA1 modela el comportamiento de la acción con cuatro rezagos de tiempo en el precio como única variable de entrada, mientras que la red RNA2 incluye los cuatro rezagos tanto en el precio como en el índice DXY; la red RNA3 restringe a dos el número de rezagos en el índice DXY. Para la acción Preferencial Bancolombia, las estructuras presentan cuatro neuronas en la capa oculta, donde RNA4 trabaja sólo con cuatro rezagos de tiempo en el precio, RNA5 incluye cuatro rezagos tanto en el precio como en el índice DXY y la red RNA6 limita a dos el número de rezagos en el índice DXY.

Las figuras 2 y 3 muestran el desempeño de la red RNA3 tanto dentro como fuera de la muestra (pronóstico) para el precio de la acción de Ecopetrol en pesos colombianos (Col-\$); en las figuras 4 y 5 se tienen los resultados en pesos colombianos para la acción Preferencial Bancolombia (Pfbcolom) con la red RNA6. En todos los caso se encuentra que los pronósticos arrojados son muy próximos a la realidad.

Tabla 3: Comparación de resultados en estructuras con diferentes rezagos de tiempo

	<i>Ecopetrol</i>			<i>Preferencial Bancolombia</i>		
	RNA1	RNA2	RNA3	RNA4	RNA5	RNA6
RMSE (dentro de muestra)	34.220	28.030	28.480	310.65	220.71	254.43
MAPE (dentro de muestra)	0.6668	0.4898	0.5224	0.7777	0.4820	0.6564
RMSE (fuera de muestra)	69.910	74.310	63.980	451.96	420.42	416.69
MAPE (fuera de muestra)	1.4606	1.6185	1.3879	1.3219	1.2113	1.2121

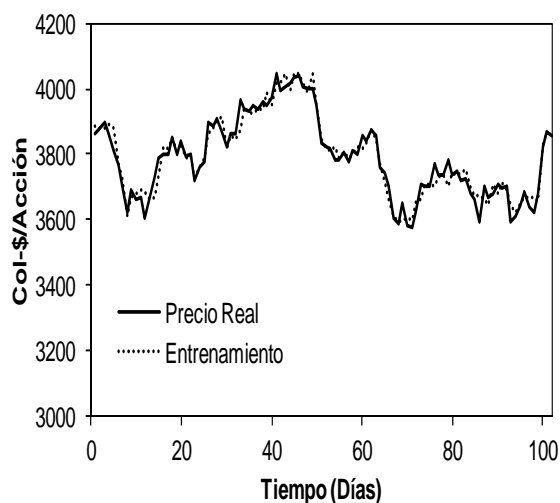


Fig. 2: Pronóstico Ecopetrol dentro de la muestra




Fig. 3: Pronóstico Ecopetrol fuera de la muestra

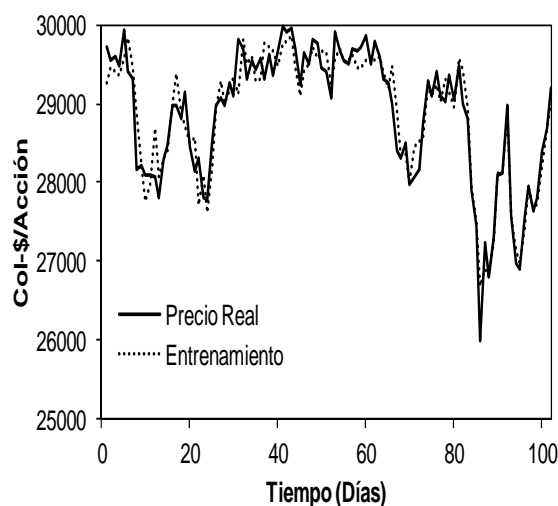


Fig. 4: Pronóstico Pfbcolom dentro de la muestra

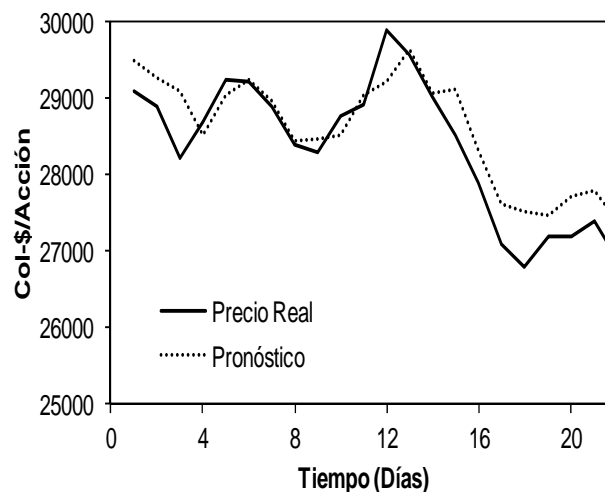


Fig. 5: Pronóstico Pfbcolom fuera de la muestra

CONCLUSIONES

El uso exitoso de las redes neuronales artificiales para el pronóstico del precio de dos de las principales acciones transadas en la bolsa de valores de Colombia, demuestra su aplicabilidad en mercados emergentes como el colombiano. Se concluyen las ventajas de las redes neuronales al ser modelos más sencillos de implementar y permitir obtener bajos errores en el pronóstico tanto dentro como fuera de la muestra.

El efecto de incluir el grado de aversión al riesgo de los inversionistas por medio del índice DXY, mejoró el desempeño de la red pero no de una manera apreciable y con diferentes rezagos de tiempo de este índice con respecto a los utilizados en la serie de precios. A pesar de que las aplicaciones mostradas se dieron en acciones de sectores económicos diferentes (energético y financiero), se encontró que prácticamente una misma estructura de red neuronal utilizando sólo la serie de precios, puede representar de forma confiable las dos acciones utilizadas

AGRADECIMIENTOS

Los autores agradecen a la Universidad de Antioquia por el apoyo financiero recibido a través del proyecto "Sostenibilidad 2011-2012".

REFERENCIAS

- Abdullah, Y. y G. Sevil, *Forecasting world stock market volatility*, International Research Journal of Finance and Economics, 15, 159-174 (2008).
- Atsalakis, G. S. y K. P. Valavanis, *Surveying stock market forecasting techniques – part II: soft computing methods*, Expert Systems with Applications, 36, 5932-5941 (2009).
- Bekiros, S. D. y D. A. Georgoutsos, *Evaluating Direction of Change Forecasting: Neurofuzzy Models vs. Neural Networks*, Mathematical and Computer Modelling, 46, 38-46 (2007).
- Chen, T., C. Su, C. Cheng y H. Chiang, *A novel Price-pattern detection method base don time series to forecast stock markets*, African Journal of Business Management, 5 (13), 5188–5198 (2011).
- Fernández F. y S. Sosvilla, *Testing Nonlinear Forecastability in Time Series: Theory and Evidence from EMS*, Economic Letters, 59, 49-63 (1998).

- García, I., A. Marbán, Y. M. Tenorio y J. G. Rodríguez, *Pronóstico de la concentración de oxono en Guadalajara-México usando redes neuronales artificiales*, Revista Información Tecnológica, 19 (3), 89–96 (2008).
- Hadavandi, E., H. Shavandi y A. Ghanvari, *Integration of genetic fuzzy systems and artificial neural networks for stock price forecasting*, Knowledge-Based Systems, 23, 800-808 (2010).
- Hao, H. N., *Short-term forecasting of stock price based on genetic-neural network*, 6th International Conference on Natural Computation, 1838-1841 (2010).
- Jing-rong, D., *Combining stock market volatility forecasts using an EWMA technique*, 4th International Conference on Wireless Communications, Networking and Mobile Computing, 5277-5280 (2007).
- Li, Y. y W. Ma, *Application of artificial neural networks in financial economics: a survey*, International Symposium on Computational Intelligence and Design, 211-214 (2010).
- Meese, R. y A. Roese, *An empirical assesment of non-linearities in models of exchange rate determination*, Review of Econometric Studies, 58, 601-619 (1991).
- Trippi, R. R. y E. Turban, *“Neural networks in finance and investing”*, Edición Revisada, 821, McGraw Hill, Nueva York, Estados Unidos (1996).
- Villada, F., E. García y J. D. Molina, *Pronóstico del precio de la energía eléctrica usando redes neuro-difusas*, Revista Información Tecnológica, 22 (6), 111-120 (2011).
- Yalama, A. y G. Sevil, *Forecasting world stock markets volatility*, International Research Journal of Finance and Economics, 15, 159-174 (2008).
- Zhang, D. y X. Zhang, *Study on forecasting the stock market trend based on stochastic analysis method*, International Journal of Business and Management, 4 (6), 163-170 (2009).